# PATENT ABSTRACTS OF JAPAN

(11)Publication number:

2001-325248

(43) Date of publication of application: 22.11.2001

(51)Int.CI.

G06F 17/21

(21)Application number: 2000-144947 (71)Applicant: FUJI XEROX CO LTD

(22) Date of filing:

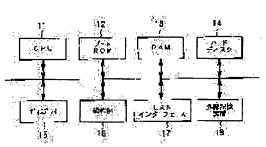
17.05.2000

(72)Inventor: IWATA NOBUO

# (54) DOCUMENT DATA PROCESSOR

# (57) Abstract:

PROBLEM TO BE SOLVED: To provide a document data processor having improved processing efficiency in contrast to a conventional document data processor which has a problem that the processing efficiency is low since the processing of an HTML parser is performed after the processing of an XML parser is performed. SOLUTION: In this document data processor, a CPU 11 reads document data and performs the processing as the XML parser. At the time of detecting a tag which is not an XML tag during the processing of the XML parser, the start tag processing part or end tag processing part of the HTML parser is activated and the pertinent part is processed. Further, at the time of finding the tag related to CDATA or a pre-format, a



**LEGAL STATUS** 

[Date of request for examination]

[Date of sending the examiner's decision of

corresponding processing is performed.

rejection] ·

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

Copyright (C); 1998,2003 Japan Patent Office

(19)日本国特許庁 (JP)

# (12) 公開特許公報(A)

(11)特許山東公開登号 特開2001-325248 (P2001-325248A)

(43)公開日 平成13年11月22日(2001.11.22)

(51) Int.CL'

織別配号

F I

ラーマユード(参考)

G06F 17/21

501

G 0 6 F 17/21

501T 5B009

#### 密査請求 京請求 請求項の数9 〇L (全10頁)

(21)出癩番号

特慮2000-144947(P2000-144947)

(22)出題日

平成12年5月17日(2000.5.17)

(71)出顧人 000005496

官士ゼロックス株式会社

東京都港区赤板二丁目17春22号

(72) 発明者 岩田 伸夫

神奈川県海老名市本第2274番地 富士ゼロ

ックス株式会社宛老名事業所内

(74)代理人 100075258

弁理士 吉田 研二 (外2名)

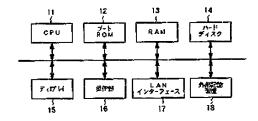
Fターム(参考) 5B009 NA05

#### (54)【発明の名称】 文書データ処理装置

#### (57)【要約】

【課題】 従来の文音データ処理装置では、XMLバーザの処理が行われた後にHTMLバーザの処理が行われるので、処理効率が低いという問題点があったが、本発明では、処理効率を向上できる文書データ処理装置を提供する。

【解決手段】 CPU11が文書データを該み込んで、XMLパーザとしての処理を行い、このXMLパーザの処理中に、XMLタグでないタグを検出すると、HTMLパーザの開始タグ処理部又は終了タグ処理部を起動して当該部分を処理し、さらにCDATA又はプレフォーマットに関連するタグであるときには、対応する処理を行う文書データ処理装置である。



. 2

#### 【特許請求の範囲】

【請求項1】 HTMLにより記述された部分文書デー タとXMLにより記述された部分文書データの少なくと も一方を含むタグ付き文書データ、

1

を処理する文書データ処理装置であって、

所定の部分文書データをHTML文書として処理し、出 力するHTMLパーザ手段と、

処理対象となったタグ付き文書データを部分文書データ ごとに順次解析し、解析の結果に応じて前記員TMLバ ータをXML文書として処理する動作とのいずれかを選 択的に行うXMLパーザ手段と、

を含むことを特徴とする文書データ処理装置。

【請求項2】 請求項1に記載の文書データ処理装置で あって、さらに、

処理対象となったタグ付き文書データのデータ型膜性を 取得する手段と、

前記データ型膜性に対応付けて享前に定義されているデ フォルトデータ型定義を取得する手段とを含み、

タ型定義に従って処理を行うことを特徴とする文書デー タ処理装置。

【請求項3】 請求項2に記載の文書データ処理装置で あって、

前記XMLパーザ手段は、処理対象となったタグ付き文 書データにXMし宣言がない場合にのみ前記取得したデ フォルトデータ型定義に従って処理を行うことを特徴と する文書データ処理装置。

【請求項4】 請求項1に記載の文書データ処理装置で

処理対象となったタグ付き文書データと、当該文書デー タに関連づけられたデータ型定義とを取得する手段と、 前記タグ付き文書データのデータ型属性を取得する手段 と.

前記データ型属性に対応付けて享前に定義されているデ フォルトデータ型定義を取得する手段とを含み、

前記XMLパーザ手段が、前記取得したデータ型定義と デフォルトデータ型定義とに従って処理を行うことを特 徴とする文書データ処理装置。

【請求項5】 請求項1から4のいずれかに記載の文書 40 データ処理装置において.

特殊タグことに、当該特殊タグに関連する部分文書デー タを処理するバーザ手段と

前記特殊タグの情報と、当該特殊タグに対応するパーザ 手段とを少なくとも一組設定する手段を含み、

前記XMLパーザ手段は、タグ付き文書データを解析 し、当該解析の結果、前記特殊タグを検出すると、当該 特殊タグに対応するパーザ手段を起動することを特徴と する文書データ処理装置。

おいて.

前記特殊タグには、少なくともCDATAに関連するタ グと、プレフォーマットに関連するタグとのいずれかを 含むことを特徴とする文書データ処理装置。

【贈求項7】 請求項1から6のいずれかに記載の文書 データ処理装置において、

さらに、各タグごとの省略可否情報を格納する手段を含

前記XMLパーザ手段は、省略可能に設定されたタグを ーザ手段を起動する動作と、当該解析された部分文書デ 10 検出すると、タグが省略されているか否かを解析し、当 該解析の結果に基づいてタグが省略されているときに は、当該省略されたタグを補完して文書データを処理す ることを特徴とする文書データ処理装置。

> 【請求項8】 第1のルールで記述された部分文書デー タと第2のルールに従って記述された部分文書データの 少なくとも一方を含む文書データ、

を処理する文書データ処理装置であって、

所定の部分文書データを前記第1のルールに従って処理 し、出力する第1パーザ手段と、

前記XMLパーザ手段が、前記取得したデフォルトデー。20、処理対象となった文書データを部分文書データどとに順 次解析し、解析の結果に応じて前記第1パーザ手段を起 動する動作と、当該解析された部分文書データを第2の ルールに従って処理する動作とのいずれかを選択的に行 う第2パーザ手段と、

を含むことを特徴とする文書データ処理装置。

【請求項9】 第1のルールで記述された部分文書デー タと第2のルールに従って記述された部分文書データの 少なくとも一方を含む文書データ、

を処理する文書データ処理プログラムであって、

30 所定の部分文書データを前記第1のルールに従って処理 し、出力する第1パーザモジュールと

処理対象となった文書データを部分文書データごとに順 次解析し、解析の結果に応じて前記第1パーザモジュー ルを起動する動作と、当該解析された部分文書データを 第2のルールに従って処理する動作とのいずれかを選択 的に行う第2パーザモジュールと、

を含む文書データ処理プログラムを格納したことを特徴 とするコンピュータ読み取り可能な記録媒体。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、構造化された文書 データを表示等するための文書データ処理装置に係り、 特にXML (Extensible Markup Language) と、HTM L(HyperText Markup Langage)との双方に対応可能な 文書データ処理装置に関する。

[0002]

【従来の技術】近年、インターネットで広く用いられる 文書データの形式としてHTMLと呼ばれるマーク付け 言語がある。HTMLは、SGML (Standard General 【語求項6】 語求項5に記載の文書データ処理装置に 50 nzed Markup Language)と呼ばれる。メタ言語文法に単

鍵して記述されている。しかし、このSGMLにより記 述された文書の処理は、種々の指定処理が可能であるも のの、処理が複雑になるため、XMLと呼ばれる簡略化

された言語が策定されつつある。また、このXMLに は、文書中に文書の居性や特定の処理の対象となるデー タ(直接表示はされないが処理装置で利用されるデー タ)を含ませることができる。

【0003】このXMLにより記述された文書データ は、HTMLと同様に取得されて処理されるのである が、従来の文書データ処理装置としてのWebブラウザ 10 いう問題点があった。 を含むパーソナルコンピュータでは、このXMLを直接 処理できないため、取得したXML文書を、HTMLに 変換する処理を行ってから、HTML文書として改めて 処理を行っている。

【0004】ととろで、XMLやSGMLでは、文書フ ァイル中または文書ファイルから参照される他のファイ ルにDTD(Data Type Difinition)を設定してシンタ ックスを宣言し、この宣言に従って文書データの処理を 行わせる。

【0005】例えば、SGMLでは、マーク付けのため 26 のタグ(特定の処理を行わせるべきコンテンツを囲むデ ータ)をDTDを用いて定義できる。このSGMLで は、終了を表すタグを省略して記載できるようにDTD を用いた定義を作成できる。このように終了のタグを省 略した文書データを処理する場合、当該タグに対するコ ンテンツであるが否かを判別し、そうでないコンテンツ が見いだされた場合に、終了タグがあったものとして処 理する必要がある。具体的にHTMLの<P>(段落の開 始タグ) は、対応する終了タグ (</P>) を省略できるこ とをDTDを用いて定義できる。さらにSGMLでは、 文書データ中に必須の開始タグを省略可能と定義するこ ともできるようになっている。

【0006】とれに比べ、XMLは、開始タグと終了タ グの種類が制限されるとともに、コンテンツのタイプも 参照データとタグとの関係でSGMしより限定的に定め られている。 すなわち、SGMLでは、コンテンツ中の タグや(画像データなどに対する)参照データを処理す るPCDATA (Parsed Character Data) と、タグを 無視して参照データのみを処理するRCDATA (Rap) る文字列として扱うことができるCDATA(Characte r Data) との3種類があったが、XMLでは、PCDA TAのみが利用可能である。ここで、CDATAは、衰 示や印刷の目的でなく、javaScriptによるス クリプトプログラムの記述に利用されている。

【0007】とのため、従来の文書データ処理装置で は、XMLとHTMLの双方に対応させるために、XM Lデータを処理してHTMLデータに変換し、次に変換 後のHTMLデータを処理することとしている。

[0008]

【発明が解決しようとする課題】このように、上記従来 の文書データ処理装置では、XMLをHTMLへ変換す るためにXMLバーザを実行し、さらにこのバーザの処 理結果に基づいてHTMLバーザを実行するので、処理 負荷が大きくなる。また、既存のHTML文書の多く は、DTD定義が関連づけられていないものが多く、X MLバーザが正常に動作しない場合がある。さらに、既 存のHTML文書では、終了タグが省略されているもの。 が多く、XMLバーザがそのまま正常に処理できないと

【0009】さらに、近年のHTML文書データには、 JavaScriptのための<SCRIPT>タグや、スタイ ルシートの指定のための<STYLE>タグ等が設定されてお り、コンテンツがCDATAとして処理されることが前 提となっているものがある。さらに、PRE、タグと呼ばれ るタグを用いて、スペースや改行をコンテンツ通りに表 示する手法が用いられたものもある。これらの文書デー タは、XMLバーザではそのまま正常に処理することが できない。

【0010】本発明は上記実績に鑑みて為されたもの で、HTML中に混在するXMLデータを正常に処理で き、かつ処理効率を向上できる文書データ処理装置を提 供することを目的とする。

[0011]

【課題を解決するための手段】上記従来例の問題点を解 決するための請求項1記載の発明は、文書データ処理装 置であって、HTMLにより記述された部分文書データ とXMLにより記述された部分文書データの少なくとも 一方を含むタグ付き文書データ、を処理する文書データ 30 処理装置であって、所定の部分文書データをHTML文 着として処理し、出力するHTMLバーザ手段と、処理 対象となったタグ付き文書データを部分文書データごと に順次解析し、解析の結果に応じて前記員TMLバーザ 手段を起動する動作と、当該解析された部分文書データ をXML文書として処理する動作とのいずれかを選択的 に行うXMLバーザ手段と、を含むことを特徴としてい

【0012】このXMLバーザ手段により、XMLパー ザの解析処理中に検出されたHTML部分の文書データ aceable Character Cata)と、タグも参照データも単な 40 がHTMLパーザにより処理され、処理効率を向上でき る。また、上記従来例の問題点を解決するための論求項 2記載の発明は、請求項1記載の文書データ処理装置に おいて、処理対象となったタグ付き文書データのデータ 型属性を取得する手段と、前記データ型属性に対応付け て事前に定義されているデフォルトデータ型定義を取得 する手段とを含み、前記XMLパーザ手段が、前記取得 したデフォルトデータ型定義に従って処理を行うことを 特徴としている。これにより、DTD定義が関連づける れていない文書データに対してもデフォルトのDTDを 50 適用でき、正常に文書データを処理できる。

【0013】さらに、XMLパーザ手段は、処理対象と なったタグ付き文書データにXML宣書がない場合にの み前記取得したデフォルトデータ型定義に従って処理を 行うことも好資である。

【0014】また、上記従来例の問題点を解決するため の語求項4記載の発明は、語求項1に記載の文書データ 処理装置であって、処理対象となったタグ付き文書デー タと、 当該文書データに関連づけられたデータ型定義と を取得する手段と、前記タグ付き文書データのデータ型 届性を取得する手段と、前記データ型属性に対応付けて 10 Ml2に格納されているプログラムをRAM13上にロ 亭前に定義されているデフォルトデータ型定義を取得す る手段とを含み、前記XMしパーザ手段が、前記取得し たデータ型定義とデフォルトデータ型定義とに従って処 選を行うことを特徴としている。

【0015】さらに、上記従来例の問題点を解決するた めの請求項5記載の発明は、請求項1から4のいずれか に記載の文書データ処理装置において、特殊タグごと に、当該特殊タグに関連する部分文書データを処理する パーザ手段と、前記特殊タグの情報と、当該特殊タグに 対応するパーザ手段とを少なくとも一組設定する手段を 20 処理に関連するプログラムを格納している。RAM13 含み、前記XMLバーザ手段は、タグ付き文書データを 解析し、当該解析の結果、前記特殊タグを検出すると、 当該特殊タグに対応するバーザ手段を起動するととを特

【0016】また、ここで前記特殊タグには、少なくと もCDATAに関連するタグと、プレフォーマットに関 連するタグとのいずれかを含むことが好ましい。

【0017】さらに、上記従来例の問題点を解決するた

めの請求項7記載の発明は、請求項1から6のいずれか に記載の文書データ処理装置において、さらに、各タグ 30 ース17は、LAN(LocalArea Network)又はインタ ごとの省略可否情報を格納する手段を含み、前記XML パーザ手段は、省略可能に設定されたタグを検出する。 と、タグが省略されているが否かを解析し、当該解析の 結果に基づいてタグが省略されているときには、当該省 略されたタグを補完して文書データを処理することを特 徴としている。これによりタグが省略された文書データ に対しても正常な処理を行うことができる。

【0018】上記従来例の問題点を解決するための請求 項8記載の発明は、文書データ処理装置であって、第1 従って記述された部分文書データの少なくとも一方を含 む文書データ、を処理する文書データ処理装置であっ て、所定の部分文書データを前記第1のルールに従って 処理し、出力する第1パーザ手段と、処理対象となった 文書データを部分文書データごとに順次解析し、解析の 結果に応じて前記第1パーザ手段を起動する動作と、当 該解析された部分文書データを第2のルールに従って処 選する動作とのいずれかを選択的に行う第2パーザ手段 と、を含むことを特徴としている。

[0019]

【発明の実施の形態】本発明の実施の形態について図面 を参照しながら説明する。本発明の実施の形態に係る文 書データ処理装置は、パーソナルコンピュータであり、 具体的には図1に示すように、CPU11と、ブートR OM12と、RAM13と、ハードディスク14と、デ ィスプレイ15と、操作部16と、LANインタフェー ス17と、外部記憶装置18とから基本的に模成されて いる。

【0020】CPU11は、電源投入直後にブートRO ードして実行する初期化処理を行う。この初期化処理に より、CPU11は、ハードディスク14に格納された オペレーティングシステムをRAM13上にロードし、 処理を開始する。そして、CPU11は、操作部16か ら入力される指示により、文書データの処理を行うブラ ウザをハードディスク14からRAM13上にロードし て処理を行う。このブラウザの処理については、後に詳 しく説明する。

【0021】 ブートROM12は、CPU11の初期化 は、CPUllのワークメモリとして動作する。ハード ディスク14は、CPU11が処理する各種プログラム を格納している。またこのハードディスク14は、CP U11の処理に必要なデータ(例えば事前に設定された デフォルトDTD等)を格納している。

【0022】ディスプレイ15は、CPU11から入力 される指示により、種々のデータを表示出力する。操作 部16は、キーボードやマウス等であり、ユーザが行う 操作の内容をCPUllに伝達する。LANインタフェ ーネットを経由してWebサーバに接続されており、C PUllから入力される指示によりネットワークを介し てデータを送信し、また、ネットワークを介して到来す るデータを受信してCPUllに出力する。

【0023】外部記憶装置18は、プロッピー(登録商 標)ディスクや光磁気ディスク等、光学的又は電磁気的 にデータを保持し、コンピュータにより読み取り可能な 記録媒体等からデータを読み出してCPUllに出力す る。CPU11は、この外部記憶装置18から読み出し のルールで記述された部分文書データと第2のルールに 40 たデータをハードディスク 1.4 に処理プログラムとして インストールする。

> 【0024】ことでCPU11の文書データ処理につい て説明する。本実施の形態に係るCPU11が処理する 文書データ処理のためのブラウザブログラムは、図2に 示すように、TCP/!Pプロトコル解析部21と、X MLバーズ部22と、HTMLバーズ部23と、ブラウ ザコア部24と、描画部25とから構成されている。ま た、HTMLパーズ部23は、プレフォーマット処理部 31と、CDATA処理部32と、開始タグ処理部33 50 と、終了タグ処理部3.4とから構成されている。ここ

で、XMLパーズ部22が、本発明のXMLパーザ手段 又は第2パーザ手段に、HTMLパーズ部23が本発明 のHTMLパーザ手段又は第1パーザ手段にそれぞれ相 当している。また、プレフォーマット処理部31とCD ATA処理部32とが本発明の特殊タグに対応するパー ザ手段に相当し、プレフォーマット処理すべき文書デー タは、特殊タグ「<PRE>」に関連づけられ、CDATA に関連する特殊タグは、「<SORIPT>」等である。

【0025】TCP/!Pプロトコル処理部21は、T CP/!Pプロトコルによってネットワークを経由して 10 ードディスク14からロードし (S1)、デフォルトD 文書データを取得し、XMLバーズ部22に出力する。 ことで、TCP/IPプロトコル処理部21が取得する 文書データは、具体的に図3で示すようなものである。 この図3において、文字「<」と、「>」とで囲まれてい る部分(例えば先頭の<mmL>)がタグと呼ばれる。ま た。このタグのうち、「</」で始まるものが終了タグで あり、そうでないものが開始タグである。図3に示すよ うに、本実施の形態の文書データ処理装置において想定 している文書データは、開始タグとコンテンツデータと 終了タグとからなる基本構造が入れ子になっているもの 20 などがある。この処理SSにおいて、XMLタグであれ である。すなわち、関始タグ<HTML>と、終了タグ</HML >の間のコンテンツには、さらに開始タグ<BCDY>と、終 了タグ</BCDY>とに囲まれたコンテンツがあり、さら に、このコンテンツ内にも基本構造が複数含まれてい る。尚、この図3の文書データにおいては、数多く存在 するHTML文書と同様に、例えば「<BR>」タグに対応 する終了タグが省略されている。

【0026】また、図3には現れていないが、XMLに おいては、「/>」で終了するタグは、便宜的に終了タグ として扱われるのが一般的である。

【0027】ととで、CPU11がTCP/IPプロト コル処理部21で取得した文書データに対して行うXM Lバーズ部22としての処理を図4を参照して説明す る。尚、以下の説明において、ハードディスク14に は、動作パラメータと、デフォルトデータ型定義に相当 するデフォルトDTDとが事前に設定され、格納されて いるものとする。ここで、動作パラメータとは、図5に 示すように、開始タグ処理部33へのポインタ(A) と、終了タグ処理部34へのポインタ(B)と、CDA て処理すべきタグ名の配列(D)と、プレフォーマット 処理部31へのポインタ(E)と、プレフォーマット処 運部31で処理すべきタグ名の配列(F)と、終了タグ の省略の可否を表すフラグ(G)とを関連づけたもので あり、デフォルトDTDは、要素宣言と、属性宣言とを 含み 要素宣言は、図6(a)に示すように、識別子 (H)と、タグ名(i)と、タイプ(j)と、開始タグ 及び終了タグの省略可否を表すフラグ(K)と、コンテ ンツに含まれる可能性のあるタグのリスト(L)とを関 示すように、識別子 (M) と、タグ名 (N) と、 **反性名** (O) と、属性値のタイプ (P) とを関連づけたもので あり、居性値タイプが列挙型 (enumeration) である場 合には、さらに取りうる値の配列(Q)が関連づけられ ている。これらの図5及び図6において配列やリスト は、通常広く知られるように、NULLで配列の終了を 識別することとしている。

【0028】CPU11は、XMLバーズ部22の処理 として、図4に示すように、まず、動作パラメータをハ TDをハードディスク14からロードする(S2)。そ して、文書データを読込み(S3)、文書データが終了 したか否かを調べ(S4)、終了していれば(Yesな らば)、処理を終了する。

【0029】また、処理S4において、終了していなけ れば(Noならば)、読み込んだ文書データがXMLタ グであるか否かを調べる(S5)。ここでXMLタグと は、「マイ」や、「マイ」で開始する特別なタグである。こ のようなタグとして例えば、「セニ」で始まるコメント ば(Yesならば)、XMLタグの処理を実行して(S 6) 処理S3に戻って処理を続ける(A)。一方、X MLタグでなければ(Noならば)。 さらに開始タグで あるか否かを調べ (S7)、 関始タグであれば (Yes ならば)、当該開始タグのタグ名をキーとしてデフォル トDTDを参照し、開始タグ処理部33へのポインタを 取得し、読み込んだ文書データを引麩として開始タグ処 選部33を起勤する(S8)。この開始タグ処理部33 の動作については後述する。

【0030】そして、開始タグ処理部33の処理が完了 すると、CPUllは、XMLパーザの処理を再開し、 処理S8で処理した開始タグがCDATAとして処理す べきタグであるが否かを動作パラメータを参照して検査 し(S9)、CDATAとして処理すべきタグであれば (Yesであれば)、CDATA処理部32を起勤する (S10)。CPUllは、このCDATA処理部32 の動作として、対応する終了タグが読み込まれるまでの 間、CDATAとして処理し、木構造に追加する処理を 行う。そして、CDATA処理部32の動作が完了する TA処理部32へのポインタ(C)と、CDATAとし、40 と、CPU11は、処理S3に戻ってXMLパーザの処 選を続ける。

【0031】一方、処理S9において、CDATAとし て処理すべきタグでなければ(Noであれば) さらに 当該開始タグがプレフォーマット処理すべきタグである か否かを動作バラメータを参照して検査し(\$11)、 プレフォーマット処理すべきタグであれば (Yesなら ば). プレフォーマット処理部31を起動する(S1 2)。そしてCPU11は、プレフォーマット処理部3 1の処理として、当該タグに対応する終了タグが読み込 連づけたものである。また、属性宣言は、図6(b)に 50 まれる間、PCDATAとして木樽造に追加する処理を (6)

行う。このプレフォーマット処理部31では、改行コー ドを検出すると、改行タグ<BR>に置き換える処理を行 う。そして、CPUllは、プレフォーマット処理部3 1の処理が完了すると、処理S3に戻ってXMLバーザ の処理を続ける。また、処理S!1において、プレフォ ーマット処理すべきタグでなければ、そのまま処理S3 に戻ってXMLパーザの処理を続ける。

【0032】さらに、CPU11は、処理S7におい て、開始タグでなければ(Noならば)、読み込んだ文 そして、終了タグであれば (Yesならば)、終了タグ 処理部34を起動し(S14)、終了タグ処理を行い、 処理S3に戻って処理を続ける。ことで、終了タグ処理 部34の処理内容については、後述する。

【0033】また処理S13において、終了タグでなけ れば(Noならば)、通常のコンテンツとして処理を行 い(S15)、処理S3に戻って処理を続ける。

【0034】ここで、CPU11が行う開始タグ処理部 33の動作について説明する。CPU11は、開始タグ 処理部33を読み込まれた文書データを引数として起動 20 【0038】尚、ここまでの説明においては、デフォル し、まず、読み込まれたタグの要素を木櫓造の現時点で ポイントしている要素の1レベル下位に追加し、追加し た要素を新たに現在の要素としてポイントする。また最 初のタグであれば(木樽造がなければ)、この最初のタ グを木槿造の最初のレベル(ルート)として登録し、当 該ルートを現在の要素としてポイントする。

【0035】具体的に図4に示した文書データに対し、 CPUllは、図7に示す木構造を形成する。すなわ ち、図4の文書データの1行目の«HML)を開始タグとし て認識し、開始タグ処理部33の処理としてこの「HTM 30 1」を木構造のルートとして設定してポイントし

(X)、次に2行目の«HEAD»をさらに開始タグとして認 識して現在ポイントしている要素(HTML)より1レベル 下位に「HEAD」の要素を追加して(Y)、この「HEAD」 をポイントする。さらに3行目の「TITLE」も開始タグ であるので、さらに!レベル下位に「TITLE」の要素を 付加し、引き続く「HOME PAGE」をPCDATAとして 付加する(2)。

【0036】また、ここで、CPU11が行う終了タグ 処理部34の動作について説明する。CPU11は、終 46 要素を取得しておき、ロードされたDTDを参照して、 了タグ処理部34を読み込まれた文書データと木構造中 で現在ポイントしている要素とを引数として起動し、X MLの木樽造の要素をHTMLとして解析する処理を行 って、当該要素をHTML文書に変換してRAM13に 格納し、木構造中でポイントしている位置を1レベル上 位に設定して、新たに現在の要素としてポイントする。 具体的に図4及び図7においては、「TITLE」要素に付 加されているPCDATA「HOME PAGE」(Z)の後の 「</TITLE>」を終了タグとして認識し、開始タグ「<TIT LE>」から終了タグ「</TITLE>」までの基本構造「<TITL 50 【0042】

E-HOME PAGE</TITLE>」を見てMし文書として解析し、 HTML文書としてRAM13に格納する。そして、 「TITLE」より!レベル上位の「HEAD」(Y)をポイン トするようにして、終了タグの処理を完了する。このよ うにして、終了タグ処理部34の処理の結果として得ら れるHTML文書は、図8に示すように、行標道に変換 されたものとなる。

19

【0037】さらにCPU11は、XMLパーズ部22 の処理が完了すると、ブラウザコア部24を起動して、 膏データが終了タグであるか否かを調べる(S13)。 10 RAM!3に格納されたHTML文書(HTML及びX MLの混在した文書からXMLパーズ部22及びHTM Lバーザ部23の動作によりHTMLに変換された文 書)を参照し、この日下ML文書に基づいて描画部25 に猫画の指示を出力する。猫画部25は、文書の各行の 絶対座標やサイズ、テキストや画像部分、絶対座標やサ イズ、テキストに対するフォント、画像を参照する情報 としてのURL (Uniform Resource Locators) 等を考 慮して、ディスプレイ15に描画結果としての文書デー タの内容を表示する。

> トDTDを予めロードしているが、XMLタグ処理にお いて、データ型を宣言するタグである「 検出されたときに、当該データ型が特定のもの(例えば HTML3.2) であったときにのみデフォルトDTD をロードするようにしてもよい。また、関始タグ処理部 33の動作として、「<mwL>」タグを検出した場合に、 それまでにDTD宣言(「<!DOCTYPE」)を検出してい ないときにのみ、デフォルトDTDをロードすることと してもよい。

【0039】さらに、読み込まれた文書データに関連し て、当該文書データ内部又は当該文書データから参照さ れるDTDがある場合には、CPU11は、このDTD をロードして、デフォルトDTDの代わりに、又はデフ ォルトDTDとともにXMLパーズ部22の処理におい て利用することも好適である。

【0040】また、動作パラメータにおいて、終了タグ の省略の可否を表すフラグにより、特定のタグの省略が 可能と設定された場合には、CPU11は、当該開始タ グを読み込むと、木樽造に追加された要素の1つ上位の 省略可能であるときには、タイプがEMPTYである (「/>」で終了するタグである)か、又はEMPTYで ないが要素宣言中コンテンツに含まれる可能性のあるタ グのリストにないタグであるときに、終了タグが省略さ れたものとして終了タグ処理部34を起動する。

【りり41】また、省略可能でないタグであるときや、 EMPTYでなく、かつ要素宣言中コンテンツに含まれ る可能性のあるタグのリストにある場合には、当該タグ を木構造に追加して開始タグ処理部33を起動する。

特闘2001-325248

12

【発明の効果】本発明によれば、XMLバーズ手段が、必要に応じてHTMLバーズ手段を起動するので、文書データを効率的に処理できる。

【0043】また本発明によれば、デフォルトデータ型 定義が利用されるので、データ型定義に関連づけられて いない文書データも正常に処理できる。

【0044】さらに、本発明によれば、省略可能なタグがある場合に、終了タグを補完して処理するので、タグを省略しても正常に処理できる。

#### 【図面の簡単な説明】

【図1】 本発明の実施の形態に係る文書データ処理装置の構成ブロック図である。

【図2】 CPUllが処理するブラウザのソフトウェアの構造を表す構成ブロック図である。

【図3】 文書データの一例を表す説明図である。

\*【図4】 CPU11のXMLパーザとしての処理を表 すフローチャート図である。

【図5】 動作バラメータの一例を表す説明図である。

【図6】 DTDの一例を表す説明図である。

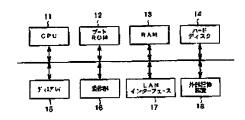
【図?】 木構造の一例を表す説明図である。

【図8】 行構造の一例を表す説明図である。

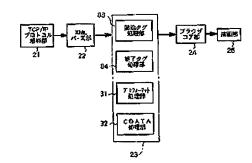
#### 【符号の説明】

11 CPU. 12 ブートROM. 13 RAM、1 4 ハードディスク、15 ディスプレイ、16 操作 19 部. 17 LANインタフェース、18 外部記憶装 置、21 TCP/!Pプロトコル解析部、22 XM Lバーズ部、23HTMLバーズ部、24 ブラウザコ ア部、25 猫画部、31 プレフォーマット処理部、 32 CDATA処理部、33 開始タグ処理部、34 终了タグ処理部。

[図1]



[22]



[図3]

```
(*Mil.)

**MEAD)

**MEAD |

**MEAD |

**MILL HOME PAGE (/*ITLE) (STYLE)

**MILL HOME PAGE (/*ITLE) (STYLE)

**MILL HOME PAGE (/*ITLE) (STYLE)

**MILL HOME **MILL HOME PAGE (/*ITLE) (JANUAR)

**MILL HOME **MILL HOME PAGE (/*ITLE) (JANUAR)

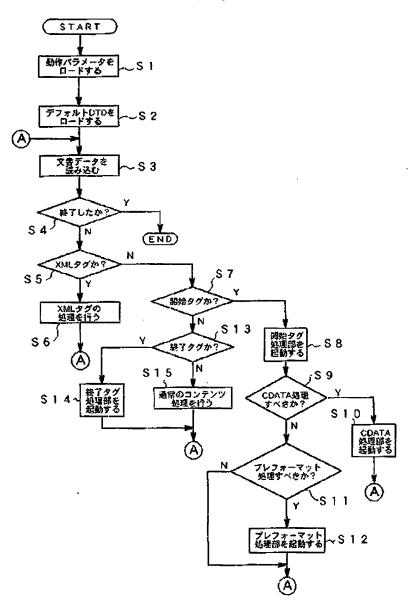
**MILL HOME PAGE (/*ITLE)

**MILL
```

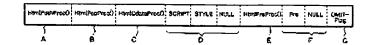
(C) XXXX Text Data

(/PRE) (/BODY) (/HTML)

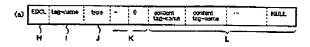
[図4]

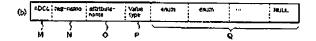


[図5]

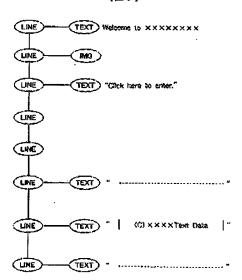


[図6]

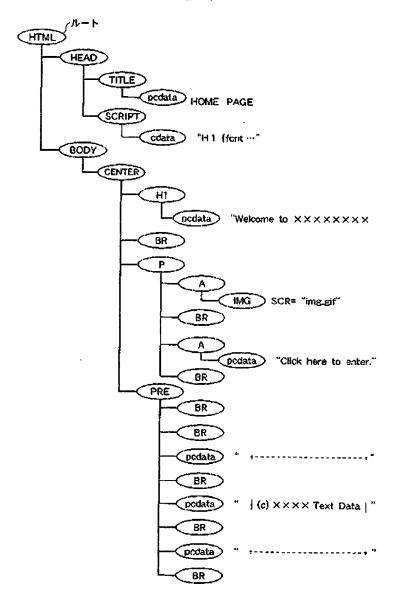




[図8]



[図7]



# This Page is Inserted by IFW Indexing and Scanning Operations and is not part of the Official Record

# **BEST AVAILABLE IMAGES**

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

BLACK BORDERS

IMAGE CUT OFF AT TOP, BOTTOM OR SIDES

FADED TEXT OR DRAWING

BLURRED OR ILLEGIBLE TEXT OR DRAWING

SKEWED/SLANTED IMAGES

COLOR OR BLACK AND WHITE PHOTOGRAPHS

GRAY SCALE DOCUMENTS

LINES OR MARKS ON ORIGINAL DOCUMENT

REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY

# IMAGES ARE BEST AVAILABLE COPY.

☐ OTHER:

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.